

## Ticari Kredi Faiz Oranlarının YSA NARX ve VAR Modelleri ile Öngörülmesi Forecasting Commercial Credit Interest Rates with ANN NARX and VAR Models

Meltem KARAATLI<sup>a</sup> Esranur DEMİRCİ<sup>b</sup> Ahmet BAYKALDI<sup>c</sup>

<sup>a</sup> Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Isparta, Türkiye. [meltemkaraatli@sdu.edu.tr](mailto:meltemkaraatli@sdu.edu.tr)

<sup>b</sup> Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme ABD, Isparta, Türkiye. [esra09393@gmail.com](mailto:esra09393@gmail.com)

<sup>c</sup> Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Bankacılık ve Finans, Isparta, Türkiye. [ahmetomurbaykaldi@hotmail.com](mailto:ahmetomurbaykaldi@hotmail.com)

MAKALE BİLGİSİ	ÖZET
<b>Anahtar Kelimeler:</b> Ticari Kredi Faiz Oranları YSA NARX Modeli VAR Modeli Öngörü  Gönderilme Tarihi 27 Şubat 2020 Revizyon Tarihi 23 Haziran 2020 Kabul Tarihi 10 Temmuz 2020  <b>Makale Kategorisi:</b> Araştırma Makalesi	<b>Amaç</b> – Bu çalışmada, ekonomik kalkınmanın önemli göstergelerinden biri olan, genellikle orta ve uzun vadeli olarak gerçekleşen, özel sektör yatırım kararları üzerinde belirleyici bir etkisi olan ticari kredi faiz oranları Yapay Sinir Ağları (YSA) Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) ve Vektör Otoregresif (VAR) modelleri ile öngörülme çalışılmıştır. <b>Yöntem</b> – Bu amaçla bankaların ticari kredilere uyguladıkları faiz oranı üzerinde doğrudan ya da dolaylı etkisi olduğu düşünülen makroekonomik altı değişken tespit edilmiştir. Çalışmada kullanılan veriler EVDS (Elektronik Veri Dağıtım Sistemi), Investing ve Paragaranti veri tabanlarından elde edilmiş olup Ocak 2010 – Haziran 2019 dönemi aylık verileri kapsamaktadır. YSA NARX Modeli ile yapılan öngörü çalışmasının performansı, doğrusal model özelliğine sahip öngörü gücü yüksek bir modelleme tekniği olan VAR Modeli ile karşılaştırılmıştır. <b>Bulgular</b> – Analiz sonucunda dört farklı performans değeri sonuçlarına bakılarak (MAD, MAPE, MSE, RMSE) doğrusal olmayan YSA NARX Modelinin doğrusal model özelliğine sahip olan VAR Modeline göre oldukça iyi sonuçlar verdiği görülmüştür. Sonuç olarak önemli bir makroekonomik gösterge olan ticari kredi faiz oranlarının tahmini ve öngörüsü için doğrusal olmayan modellemenin daha iyi sonuçlar verdiği görülmüştür. <b>Tartışma</b> – Türkiye gibi gelişmekte olan ülkelerde finansal piyasalar aşırı değişken, kırılgan, siyasi ve toplumsal risklere karşı oldukça duyarlıdır. Bundan dolayı makroekonomik değişkenlerin durağan bir eksende yer alması mümkün olmamaktadır. Bu gibi ekonomilerde, zaman serisi veri setine dayalı regresyon analizleri yoluyla yapılan öngörü çalışmalarından doğru ve tutarlı sonuçlar elde etmek oldukça zordur. Bu nedenlerden dolayı durağanlığı yitirebilen değişkenlerin doğrusal olmayan ilişkilerinin varlığını modelleyebilen yöntemlerin daha doğru sonuçlar verdiği tespit edilmiştir.

ARTICLE INFO	ABSTRACT
<b>Keywords:</b> Commercial Loan Interest Rates ANN NARX Model VAR Model Forecasting  Received 27 February 2020 Revised 23 June 2020 Accepted 10 July 2020  <b>Article Classification:</b> Research Article	<b>Purpose</b> – In this study; commercial loan interest rates which are one of the important indicators of economic development, generally occur in medium and long term, and have a determining effect on private sector investment decisions was tried to be predicted with Artificial Neural Networks (ANN) Nonlinear Autoregressive Exogenous model (NARX) and Vector Autoregressive (VAR) models. <b>Design/methodology/approach</b> – For this purpose, six macroeconomic variables, which are thought to have a direct or indirect effect on the interest rate applied by banks to commercial loans, were identified. The data used in the study were obtained from EVDS (Electronic Data Distribution System), Investing and Paragaranti databases and cover monthly data from January 2010 to June 2019. The performance of the prediction study with YSA NARX Model has been compared with the VAR Model, which is a predictive modeling technique with a linear model featuring a high predictive power. <b>Findings</b> – As a result of the analysis, it was observed that the non-linear ANN NARX Model results are very good compared to the VAR Model, which has the feature of linear model by looking at the results of four different performance values (MAD, MAPE, MSE, RMSE). As a result, nonlinear modeling has been shown to give better results for the prediction and forecast of commercial loan interest rates, which is an important macroeconomic indicator. <b>Discussion</b> – Financial markets in emerging countries such as Turkey are hypervariable, fragile and highly sensitive to political and social risks. Therefore, it is not possible for macroeconomic variables to be located on stationarity. In such economies, it is quite difficult to obtain accurate and consistent results from the foresight studies conducted through the regression analysis based on the time series data set. For these reasons, it has been determined that the methods that are able to model the presence of nonlinear relationships of variables that may lose their stationarity, give more accurate results.

### Önerilen Atıf/ Suggested Citation

Karaatli, M., Demirci, E., Baykaldi, A. (2020). Ticari Kredi Faiz Oranlarının YSA NARX ve VAR Modelleri ile Öngörülmesi, *İşletme Araştırmaları Dergisi*, 12 (3), 2327-2343.

## 1. GİRİŞ

Ekonomide reel sektör, kısa, orta veya uzun vadeli işletme ve yatırım finansman ihtiyaçlarını çeşitli kaynaklardan sağlayabilmektedir. Bu kaynaklar; firmanın kârını dağıtmayıp sermayeye eklemesi ya da iç bünyesinden fon oluşturması gibi iç kaynaklar olabileceği gibi hisse senedi ihracı ve borçlanma yoluyla sağlanan (en yaygın olanı banka kredileri, şirket bono/tahvilleri gibi) dış kaynaklar da olabilmektedir (Yaşar, 2016: 3-4,14).

Türkiye’de banka kredilerinin yaygın olarak kullanıldığı gerçeği göz önünde bulundurulduğunda, kredi faiz oranları reel sektörün yatırım kararları üzerinde belirleyici bir etkiye ve öneme sahiptir. Bu yüzden çalışmada banka kredi faiz oranı öngörü çalışması gerçekleştirilmiştir. Kredi faiz oranlarına doğrudan veya dolaylı olarak etkisi olduğu düşünülen bağımsız değişkenlere aşağıda kısaca değinilmektedir.

Bu değişkenlerden birisi olan *Enflasyon* ile faiz oranları arasındaki ilişki literatürde oldukça fazla sayıda çalışmada yer almıştır. Bu çalışmaların birçoğunda enflasyonda meydana gelen değişimlerin faiz oranları üzerinde ciddi etkilere neden olduğu tespit edilmiştir (Telçeken ve Değirmen, 2019; Masatçı ve Darıcı, 2006; Booth ve Ciner, 2001; Benazić, 2013). Bu çalışmaların bir kısmında enflasyon - faiz oranları ilişkisi Fischer Denklemi çerçevesinde incelenerek nominal faiz oranlarındaki artışın beklenen enflasyon oranındaki artışa eşit olduğu teorisi test edilmiştir. Sonuçlar teoriyi doğrulamaktadır (Masatçı ve Darıcı, 2006; Demirgil ve Türkay, 2017).

Literatürde, bu modelde yer alan değişkenlerden *döviz kuru* ile faiz oranları ilişkisinin incelendiği çeşitli çalışmalarda bu iki değişkenin arasında karşılıklı ve kuvvetli etkileşimin olduğu tespit edilmiştir. Gelişmekte olan pek çok ülkenin özellikle kriz dönemlerinde, yerli paranın satın alma gücünü korumak, yurt dışı yatırımcıların ülkeye girişlerini teşvik etmek ve dövizde oluşan spekülasyon ortamından uzak durmak amacıyla faiz enstrümanından sıklıkla yararlanılmaktadır (Ayla, 2019; Sever ve Mızrak, 2007; Demirgil ve Türkay, 2017).

Kredi değerliliğinin tespit edilmesinde yararlanan *CDS primleri* son dönemlerde kullanılan önemli göstergelerden biri haline gelmiştir. Bu çalışmada yer alan modele eklenen değişkenin çeşitli çalışmalarda finansal bir risk göstergesi olarak döviz kuru ve faiz oranları ile ilişkisi incelenmiş ve aralarında anlamlı ilişkiler bulunmuştur (Özpinar vd., 2018), (Conkar ve Vergili, 2017).

Bu çalışmada yer alan diğer bir bağımsız makroekonomik değişken olan *para arzı ile* faiz ve enflasyon arasındaki ilişkilerin incelendiği çeşitli çalışmalarda para arzı ile faiz arasında negatif yönlü, enflasyon ile pozitif yönlü bir ilişki olduğu sonucuna varılmıştır (Cesur, 2006; Yavuz, 2012; Demirgil ve Türkay, 2017).

Para arzı ile faiz ilişkilerinin açıklanmasına ciddi bir katkı sunmuş olan Post Keynesyen yaklaşıma göre piyasada ortaya çıkan kredi talepleri, bankalardaki kredi kaynaklarından biri olan mevduatların artışını, dolayısıyla da para arzındaki artışı tetiklemektedir. Bankalar kredi kaynağı olan mevduatlardaki artışı kredilere dönüştürülerek bu çalışmada kullanılan diğer bir değişken olan *kredi hacminin* artmasına yol açmaktadır. Merkezi otoritenin (Merkez Bankaları) de paranın fiyatını belirleyerek dahil olduğu bu mekanizma içerisinde faizlerin genel seviyesi belirlenmektedir (Nesanur, 2011).

Bu çalışmada kullanılan değişkenlerden biri olan Devlet İç Borçlanma Senedi'nin (DİBS) literatürde döviz kurlarından ve enflasyondan etkilendiği sonucuna varılan çalışmalar mevcuttur (Aytekin ve Dube, 2016; Yavuz, 2012). Devletin kamu açıklarını kapatmada sıklıkla başvurduğu yöntemlerden biri olan iç borçlanma senedi/tahvili, ihracında etkin bir borçlanma izlenmediği ve kamu borç stokunun aşırı artış gösterdiği ekonomilerde bu durumun enflasyon, faiz ve gayri safi milli hâsıla (GSMH) gibi değişkenleri de olumsuz yönde etkilediği görülmektedir (Demir ve Sever, 2008).

Yukarıda bahsedilen bağımsız değişkenlerin, bağımlı değişken olarak seçilen faiz (ticari kredi faizleri) oranları ile doğrudan veya dolaylı ilişkilere sahip olduğu sonucuna varılmıştır. Bu durum göz önüne alınarak Yapay Sinir Ağları (YSA) Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) ve Vektör Otoregresif (VAR) Modelleri ile yapılan öngörü çalışmasında bu değişkenlerden yararlanılmıştır.

Bu çalışmada giriş bölümünden sonra yer alan ikinci bölümde finansal alanda yapılan çalışmalar ile YSA ve ekonometrik analizler kullanılarak yapılan karşılaştırmalı analiz çalışmalarına yer verilmiştir. Üçüncü bölümde, uygulamada kullanılan VAR Modeli ve dördüncü bölümde YSA NARX Modelleri anlatılmıştır.

Beşinci bölümde ise iki farklı yöntemle ticari kredi faiz oranlarının öngörüsünde bulunulmuş ve yöntemlerin performans ölçütleri karşılaştırılmıştır.

## 2. LİTERATÜR TARAMASI

Çalışmanın bu bölümünde yer alan literatür taraması iki farklı şekilde ele alınmıştır. Tablo 1’de yer alan literatür taraması makroekonomik değişkenlerin incelendiği çalışmaları, Tablo 2’de yer alan literatür taraması ise YSA ve ekonometrik yöntemlerin karşılaştırmalı incelendiği öngörü ve tahmin çalışmalarını göstermektedir.

**Tablo 1.** Çalışmada Kullanılan Makroekonomik Değişkenlerin İncelendiği Çalışmalar

Yıl	Yazar	Konu	Sonuç
2001	G. Geoffrey BOOTH Çetin CINER	Enflasyon ve faiz oranları arasındaki ilişki incelenmiştir.	Fisher Hipotezi çerçevesinde 9 Avrupa ülkesinin verilerinden yararlanılarak nominal faiz oranları ile beklenen enflasyon verileri arasında uzun dönemli birebir ilişkinin varlığı tespit edilmiştir.
2002	Daniel LEIGH Marco ROSSI	Döviz kurları ile enflasyon (TEFE-TÜFE) arasındaki ilişkiye Türkiye Ekonomisi perspektifinde bakılmıştır.	Türkiye’de döviz kurları ile enflasyon arasında güçlü bir bağıntının olduğu, özellikle döviz kurları ile TEFE arasındaki açıklayıcı bağın daha kuvvetli olduğu sonucuna ulaşıldı.
2006	Fatma CESUR	Para arzı (M1, M2, M3) ve enflasyon (TEFE-TÜFE) arasındaki ilişki incelenmiştir.	TEFE verilerinin para arzındaki (M1 ve M2) değişmelerden pozitif yönde ve kuvvetli şekilde, etkilendiği gözlemlenmiştir.
2011	Özge NESANIR	Para arzı (M2) ile ticari banka kredileri toplamı arasındaki ilişki analiz edilmiştir.	Para arzındaki genişlemenin banka kredilerine olan talepten kaynaklandığı, banka kredilerden para arzına doğru nedensellik ilişkisinin bulunduğu tespit edilmiştir.
2013	Manuel BENAŽIĆ	Beklenen enflasyon oranlarındaki değişim ile nominal faiz oranları arasındaki ilişki (Fisher Etkisi) Hırvatistan ekonomisi açısından incelenmiştir.	Beklenen enflasyon değerleri ile nominal faiz oranları arasında özellikle uzun dönemde ilişkilerin varlığına ulaşılmıştır.
2013	Maureen WERE Joseph WAMBUA	Banka kredi faizleri, GSYİH ve Enflasyon Oranları arasındaki ilişki Kenya ekonomisi için incelenmiştir.	GSYİH’deki büyümenin faiz oranlarını düşürücü etkisinin gözlemlendiği, enflasyon oranlarının etkisinin önemsiz seviyede olduğu, bankaya özgü değişkenlerin etkisinin daha fazla olduğu sonucuna varılmıştır.
2017	Biswajit MAITRA	Para arzı ve döviz kurunun nominal faiz oranları ile olan ilişkisi incelenmiştir.	Döviz kurundan faiz oranlarına doğru negatif ilişkinin varlığı tespit edilmiştir. Para arzının faiz oranlarına olumsuz etkisi olduğu belirlenmiştir.
2017	Bünyamin DEMİRGİL Hakan TÜRKAY	Para arzı, kamu iç borç stoku, döviz kuru, enflasyon, LIBOR faiz oranı, tüketici güven endeksi gibi değişkenlerin faiz oranları (mevduat) üzerindeki etkisi incelenmiştir.	Değişkenlerin faiz oranlarını etkilediği, faiz oranı ile döviz kuru ve enflasyon arasında pozitif, para arzı ile negatif yönlü ilişkinin var olduğu tespit edilmiştir.

2019	Ömer ÖZPINAR Hamit ÖZMAN Osman DORU	USD-TL döviz kuru, gösterge faizi ve CDS verileri arasındaki ilişki incelenmiştir.	USD-TL'nin yanında gösterge faizin de CDS seviyesi üzerinde etki gücüne sahip, anlamlı bir değişken olduğu tespit edilmiştir.
------	---	--	---

**Tablo 2.** Yapay Sinir Ağları ve Ekonometrik Yöntemlerin Karşılaştırmalı İncelendiği Tahmin ve Öngörü Çalışmaları

Yıl	Yazar	Konu	Sonuç
2007	Chakradhara PANDA Vathsala NARASIMHAN	1997-2004 yılı arasındaki 497 haftalık Hint Rupisi/USD döviz kuru verisinin YSA, Doğrusal Otoregresif (LAR) ve Random Walk (RW) modellerine dayalı tahmin performanslarının karşılaştırılması yapılmıştır.	YSA diğer iki doğrusal tahmin modeline göre belirgin derecede iyi bir tahmin performansı göstermiştir.
2008	Şenol ALTAN	İlk olarak YSA ve VAR modelinden yararlanarak döviz kuru öngörüsünde bulunulmuştur. Bu iki farklı model karşılaştırıldıktan sonra iki modelde de bulunan öngörüler "öngörülerin birleştirilmesi yöntemiyle" birleştirilmiştir.	Doğrusal olmayan YSA modeli doğrusal bir model olan VAR modeline göre çok daha iyi sonuçlar vermiştir. Fakat bu iki modelden elde edilen öngörü değerlerinin birleştirilmesi başarıyı arttırmıştır.
2009	Yeşim HELHEL	YSA ve VAR modelinden yararlanarak döviz kuru tahmininde bulunulmuştur. Sonrasında ise bu iki model karşılaştırılmıştır.	Doğrusal olmayan YSA modeli doğrusal bir model olan VAR modeline göre çok daha iyi sonuçlar vermiştir.
2010	Yohan+es Budiman WIJAYA Togar Alam NAPITUPULU	Hisse senedi borsasından elde edilen 7 girdi ve 1 çıktıdan oluşan verileri kullanarak çok katmanlı ve sigmoid fonksiyonlu YSA ve ARIMA yöntemleri ile öngöründe bulunulmuştur. Daha sonra her iki modelin öngörü performansı karşılaştırılmıştır.	YSA modeli, doğrusal olmayan verilerdeki mevcut örüntüyü öğrenip ARIMA modeline göre daha düşük hatalı tahmin ortaya koymuştur.
2013	Mohammad VALIPOUR Mohammad Ebrahim BANIHABIB Seyyed Mahmood Reza BEHBAHANI	Baraj rezervuarı su girişinin ARMA, ARIMA, Dinamik ve Statik yapılı YSA Modelleri yoluyla tahmin edilip bu modellerin tahmin performansları karşılaştırılmıştır.	Tahmin performansları en düşükten en yükseğe doğru; Sigmoid Fonksiyonlu Dinamik YSA, ARIMA, ARMA ve Radyal fonksiyonlu YSA olarak sıralanmıştır.
2014	Ayodel Ariyo Adebisi ADEREMI Oluyinka ADEWUMI Charles Korede AYO	Dell Inc. Şirketinin (NYSE) borsasındaki hisse senedi fiyatlarına ait verilerin kullanılarak Yapay Sinir Ağları ve ARIMA modellerinin öngörü performansları karşılaştırılmıştır.	Her iki modelin tahmin performansı kabul edilebilir sınırlardadır. Fakat YSA'nın tahmin performansının belirgin bir üstünlüğe sahip olduğu gözlenmiştir.
2014	Oscar CLAVERIA Salvador TORRO	İspanya Katalonya bölgesinde turizm talebi ile ilgili (varış ve geceleme) 2001-2009 dönemi verilerini Doğrusal yöntemler olan ARIMA ve SETAR ile doğrusal olmayan YSA yöntemine ait tahmin performansları ile karşılaştırmıştır.	Bu çalışmada ARIMA modelinin tahmin performansı daha iyi çıkmıştır. Mevsimsellik içeren orijinal bir serinin durağan hale getirilmesi seride veri kaybına yol açmaktadır. Veri kaybının YSA'nın doğrusal olmayan verilerdeki ilişkileri daha iyi modelleme

			yeteneğine bir engel oluşturduğu tespit edilmiştir.
2015	<b>Fernando Sánchez LASHERAS</b> <b>Francisco Javier de Cos JUEZ</b> <b>Ana Suárez SANCHEZ</b> <b>Alicja KRZEMIEN</b> <b>Pedro Riesgo FERNANDEZ</b>	New York Ticaret Borsası Spot Bakır Fiyat verilerinden yararlanılarak ARIMA ve iki Farklı YSA modelinin (Çok Katmanlı Ağ ve Elman) tahmin performansı karşılaştırılmıştır.	Elman (Bağlam Katmanlı, bir tür kısmi tekrarlı)YSA modeli en iyi tahmin performansı göstermiştir. Performans olarak bu modeli Çok Katmanlı YSA ve en son ARIMA modeli takip etmiştir.
2016	<b>Erasmus CADENAS</b> <b>Wilfrido RIVERA</b> <b>Rafael Campos AMEZCUA</b> <b>Christopher HEARD</b>	Rüzgâr hızı ile ilgili tahmin çalışması için girdi olarak 5 değişken belirlenmiştir. Doğrusal özellikli ARIMA ve çok değişkenli bir yapay sinir ağı tekniği olan NARX modelleri ile tahmin yapılarak her iki modelin tahmin performansı karşılaştırılmıştır.	Doğrusal olmayan ve çok değişkenli veriler ile kurulan NARX modeli, tek değişkenli ARIMA modeline göre daha düşük performanslı tahmin sonuçları vermiştir.

### 3. ZAMAN SERİLERİ İÇİN VEKTÖR OTOREGRESİF MODELİ (VAR MODELİ)

VAR Modeli 1980 yılında Sims tarafından ortaya konulmuştur. Sims (1980) içsel-dışsal ayırımına karşı çıkmış, ekonometrik bir modelde yer alan her bir değişkenin birbirleri ile etkileşimi olabileceği düşüncesi ile VAR Modelini oluşturmuştur. Kısacası, değişkenler birbirlerinden farklı şekilde ele alınmamalı, içsel-dışsal değişkenler kendi aralarında bir öncelik sırasına konulmamalıdır. VAR modelinin diğer bir avantajı ise model oluşturulurken katı ekonomik teorilere bağlı olunmamasıdır. Bu modelde, değişkenlerin içsel veya dışsallığının belirlenmesi gerekmediği için araştırmacılara büyük avantaj sağlamaktadır (Davidson ve Mackinnon, 1993:685).

VAR Modelinin birçok kullanım alanı bulunmaktadır fakat en başarılı olduğu alanın öngörü olduğu düşüncesi yaygındır. Bunun nedeni ise VAR Modelinde dışsal değişken yer almadığından dolayı öngörü yapılacak zaman dilimi için dışsal değişkenler hakkında herhangi bir ekonometrik varsayım uygulanmasının zorunlu olamamasıdır. Bu özellik ise model oluşturulurken birçok kısıtlayıcı durumu ortadan kaldırmaktadır (Greene, 1993).

İki değişkenli VAR Modelinin nasıl tahminde bulunduğunu Eşitlik (1) ve (2)'de yer alan basit bir modelle açıklamak mümkündür:

$$x_t = a_{10} + \sum_{i=1}^p a_{11,i} x_{t-i} + \sum_{i=1}^p a_{12,i} z_{t-i} + \varepsilon_{1t} \quad (1)$$

$$z_t = a_{20} + \sum_{i=1}^p a_{21,i} x_{t-i} + \sum_{i=1}^p a_{22,i} z_{t-i} + \varepsilon_{2t} \quad (2)$$

Eşitlik (1) ve (2)'de yer alan  $a_{i0}$  sabit terimi,  $a_{ij,k}$  i'inci denklemdaki j'inci değişkenin k gecikmesine ait parametresini,  $\varepsilon_{it}$  ise rassal hata terimi ve p gecikme sayısını göstermektedir. Yukarıdaki modelde eşitliğin sağ tarafında bulunan değişkenlerin birbirlerinden farklı olmadıklarına dikkat edilmelidir. Sabit terimin modele dahil edilmesi durumu değişkenlerin sıfırdan farklı bir ortalamaya sahip olması durumunda gerçekleşmektedir.

### 4. ZAMAN SERİLERİ İÇİN YAPAY SİNİR AĞI NARX MODELİ

YSA biyolojik sinir sistemlerinden esinlenerek oluşturulmuştur. YSA'lar öğrenmesini girdi verilerini kullanarak gerçekleştiren, yeni bilgiler üretebilen, genellemelerde bulunabilen ve sınıflama yapabilen algoritmalarıdır (Zhang vd., 1998:35).

YSA'lar, bazı özelliklerinden dolayı hem araştırmacılar hem de uygulayıcılar için cazip bir alternatif yöntemdir. YSA'nın iyi bir tahmin ve öngörü yeteneğinin olması bu yöntemi önemli kılmaktadır. YSA'nın geleneksel yöntemlerden farklı olan en önemli özelliği veri odaklı ve kendiliğinden uyarlanabilir olmasıdır. Bu yöntem örneklerden öğrenmektedir. YSA, temeldeki ilişkilerin bilinmemesi durumunda veya bu bilgilerin

tanımlanmasının zor olduğu durumlarda bile veriler arasındaki ince fonksiyonel ilişkileri yakalar. Bu nedenlerden dolayı YSA'lar, çözümlerinin bulunması zor olan ancak yeterli veri veya gözlemi barındıran bilgiye ihtiyaç duyan problemler için oldukça uygundur. Bu anlamda çok değişkenli doğrusal ve parametrik olmayan yöntemlerden biri olarak da ele alınabilmektedir (White, 1989; Ripley, 1993; Cheng ve Titterington, 1994).

YSA'da bulunan katmanlar aynı doğrultuda bir araya toplanan nöronlardan meydana gelmektedir. Bir YSA üç temel katmandan oluşmaktadır. Bunlar sırasıyla; girdi katmanı (input layer), gizli katman (hidden layer) ve çıktı katmanı (output layer)'dir. İleri beslemeli çok katmanlı bir YSA'da ilk katmanı *girdi katmanı* oluşturmaktadır. Bu katman girilen verilerin (bağımsız değişken verileri) ağırlıklandırılarak *gizli katmana* ulaşmasını sağlamaktadır. Girdi katmanı problemi etkileyen parametrelerden meydana gelmekte ve bu katmandaki nöron sayısı ise parametre sayısından belirlenmektedir (İslamoğlu, 2015:181). Ağın son katmanı olan *çıkış katmanı* ise gizli katmandan gelen verilerin işlenmesini gerçekleştirerek dış dünyaya aktarmaktadır. Bu katmanda oluşan veriler YSA'nın problemler için oluşturduğu çözüm değerleridir (Erdoğan ve Özyürek, 2012: 88).

NARX Modeli ise, zaman serisi çalışmalarında modelleme yapılırken sıklıkla tercih edilip uygulamaya alınan doğrusal ARX (Linear Auto Regression Models) modeline dayanmaktadır. NARX'in geleneksel geri beslemeli ağ yapılarına göre daha hızlı olduğu ve daha etkili bir performans gösterdiği performans belirleyiciden tespit edilmiştir (Aşkın vd., 2011:906). Bu sebeple çalışmada Matlab R2016b yazılımındaki nntool (Neural Network Time Series Tool) aracında yer alan NARX modeli tercih edilmiştir.

NARX Modelinde ağ meydana getirecek olan nöron sayısı ile gecikme sayısı parametreleri araştırmacı tarafından belirlenebilmektedir. Eşitlik (3)'te görüldüğü üzere zaman serisinin  $t$ . değeri daha önce zaman serisinde bulunan  $p$  tane değerlerin bir fonksiyonu şeklinde ele alınmaktadır. Denkleminde fonksiyon ilişkisi elde edilmeye çalışılmaktadır (Kirbaş ve Kerem, 2016:185-187 ; Ak vd., 2016:1736 ).

$$y_t = f(y_{t-1}, \dots, y_{t-p}) + \varepsilon_t \quad (3)$$

Eşitlik (4)'te yer alan denkleminde zaman serisinin  $t$ . değerinin hesaplanması açık bir şekilde ifade edilmektedir. Denklem incelenecek olursa nöronlar arasında yer alan ağırlık değerlerini  $w_j$  ve  $v_{ij}$  ifade ederken, gizli katmanda bulunan nöron sayısını  $p$  terimi ve gizli katmanda bulunan aktivasyon fonksiyonunu ise  $f$  fonksiyonu göstermektedir.

$$y_t = w_0 + \sum_{j=1}^p w_j f(v_{0j} + \sum_{i=1}^n v_{ij} y_{t-1}) + \varepsilon_t \quad (4)$$

Gizli katmanda yer verilecek olan doğrusal olmayan aktivasyon fonksiyonu için çoğunlukla türevi çok kez alınabilen fonksiyonlar kullanılmaktadır. Geri yayılım hesaplamaları uygulanırken hata oranını düşürmek ve en elverişli ağırlık değerlerini tespit etmek için genellikle **sigmoid** (5) ve **tanjant hiperbolik** (6) fonksiyonlarından yararlanılmaktadır.

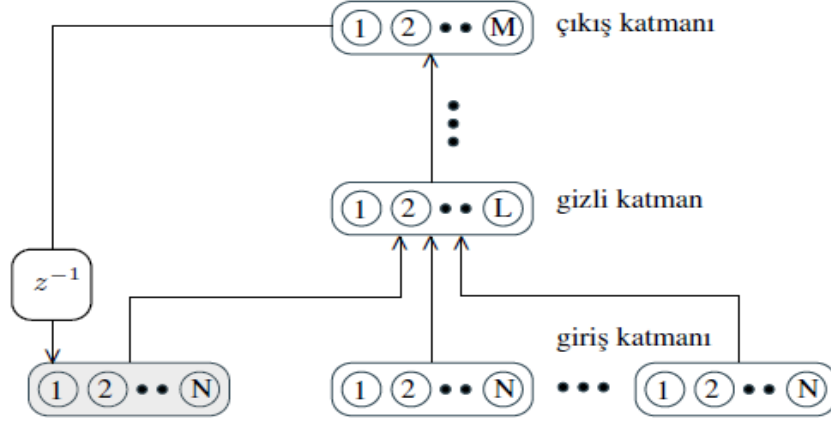
$$f(x) = \frac{1}{1+e^{-x}} \quad (5)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

Lin vd., (1996:1329) taraflarınca öneride bulunulan bir YSA ağı olan NARX doğrusal olmayan dışsal girdili otoregresif ağıdır. NARX istenilen çıktı değerlerinin geçmiş zamandaki verilere bağlı olduğu problemlerde kullanılmaktadır. NARX, çok katmanda oluşan geri beslemeli ve ileri hesaplamalı bir dinamik yapay sinir ağıdır. NARX'te yer alan "X" eksojen değerleri göstermektedir. Eksojen değer ise dışsal değişkenlerinde modele dahil edilmesini ifade etmektedir. Dinamik YSA'da gelecek değer tahmini için gecikme değerlerinden yararlanılmakta ve ağ çıkışı girişe geri besleme şeklinde uygulanmaktadır.

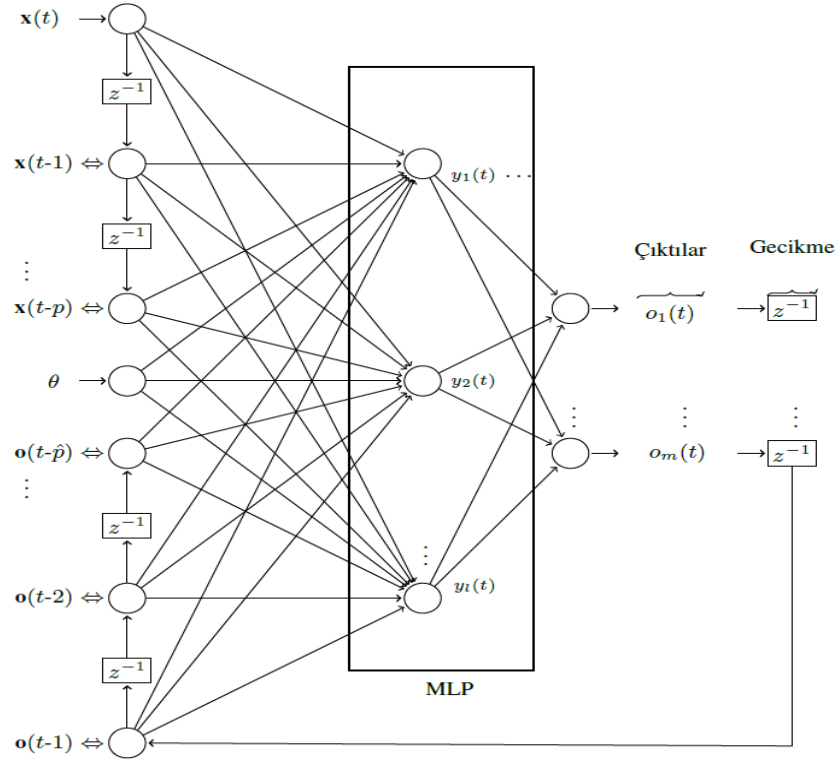
NARX ağı dışsal bağımlılıkları modelleyerek sonuçları daha iyi bir hale getirmeye yardımcı sağlayacak dışsal girdiyi modelleme özelliğini barındırmaktadır. Ayrıca bu model tahmin için fayda sağlayacak olan fazladan bilginin kullanılmasına da izin vermektedir. NARX ağlarının geleneksel geri beslemeli ağ yapılarından diğer bir farkı ise daha hızlı ve daha etkili bir şekilde öğrenmeyi gerçekleştirmesidir (Yavuz, 2018: 67).

NARX ağlarının genel yapısı yani modelin hücresel yapısı Şekil 1’de yer almaktadır. Şekilde yer alan N giriş katmanında bulunan hücre sayısını, L gizli katmanda bulunan hücre sayısını ve M ise çıkış katmanında bulunan hücre sayısını göstermektedir (Ham ve Kostanic, 2003; Haykin, 1998).



Şekil 1. NARX Ağlarının Genel Yapısı (Tatlı ve Kahvecioğlu, 2016:131)

Geri besleme katmanı tahmin edilerek elde edilen verilerden ya da gerçek verilerden meydana gelmektedir. Geri beslemeli ağların yapısı paralel ve seri paralel olarak iki farklı şekilde adlandırılmaktadır. Tahmin çıktısının geri beslemeli şekilde girişe uygulandığı modeller paralel yapı modelini kullanırken, gerçek verinin elde edilmesi ile beraber elde edilen gerçek verinin girişe geri beslemeli şekilde uygulanması işlemi seri-paralel modelde gerçekleşmektedir (Xie vd., 2009:1276). Şekil 2’de yer alan ağ yapısı NARX YSA modeline ait bir ağ yapısıdır.



Şekil 2. NARX YSA Modeline Ait Ağ Yapısı (NARX Neural Network Structure) (Tatlı ve Kahvecioğlu, 2016:131)

NARX modelinde yer alan bağımlı değişken, geçmişteki değerlerin bir fonksiyonudur. Zaman serilerinde yer alan çoğu veride bu aşamaları içermektedir. NARX modeli, aşağıdaki eşitlik (7) ile ifade edilebilir;

$$o(t) = F(o(t-1), o(t-2), \dots, o(t-\hat{p}), x(t), x(t-1), \dots, x(t-p)) \quad (7)$$

Eşitlik (7)'da yer alan  $o(t-\hat{p}) \in \mathbb{R}$  ve  $x(t-p) \in \mathbb{R}$  sırasıyla ağ çıktıları ve girdilerini,  $\hat{p}$  ve  $p$  ise sırasıyla geri besleme için uygulanacak geçmiş çıktıların ve geçmiş girdilerin sayısını ifade etmektedir. Geri besleme ve girdi katmanları zaman gecikmelidir ve geçmiş verileri barındırmaktadır (Xie vd., 2009:1330).

MatLab ntstool aracı ile kullanılabilir eğitim algoritmaları sırasıyla; Levenberg-Marquardt (LM) Method, Bayesian Regulation Method ve Scaled Conjugate Gradient Method'larıdır.

YSA, giriş ve çıkış eşleşme modelini eğitim veri seti ile sağlayabilmek için çoğunlukla geriye yayılım algoritmasından yararlanılmaktadır (Werbos, 1988). Birinci dereceden türev kullanan geriye yayılım algoritmasının eğitim verimi oldukça düşüktür. Ayrıca kötü yakınsama hızı gibi dezavantajlara da sahiptir (Hagan ve Menhaj, 1994; Ferrari ve Jensenius, 2008). Dik iniş (steepest descent) ve Newton algoritmalarından türetilen **Levenberg-Marquardt (LM)** algoritması ikinci dereceden türev gerektiren algoritmaların öğrenme hızını önemli derecede arttırmaktadır (Wilamowski ve Chen, 1999:1725). Bu yüzden LM algoritması son zamanlarda yapılan çalışmalarda ağ eğitiminde başarılı sonuçlar elde ettiği için sıklıkla kullanılmaktadır (Dohnal, 2004:364; Khosravi vd., 2006). Bu çalışmada da LM eğitim algoritmasından yararlanılmıştır. Ayrıca çalışmada tüm algoritmalar denenmiş fakat ele alınan dönemler için en iyi tahmin ve öngörü değerlerine LM algoritması ile ulaşılmıştır.

## 5. YÖNTEM

Uygulama bölümünde araştırmanın amacı, çalışmada kullanılan değişkenler ve veri seti, VAR ve YSA NARX Modelleri uygulama sonuçlarına ve iki modelin performanslarının karşılaştırılmasına yer verilmiştir.

### 5.1. Araştırmanın Amacı

Bankaların kredi faiz oranları ekonomik kalkınmada önemli bir gösterge olduğu için orta ve uzun vadeli olarak gerçekleşen özel sektör yatırım kararları üzerinde etkisi olan makroekonomik göstergelerden biridir. Bu amaçla çalışmada bankaların ticari kredilere uyguladıkları faiz oranları öngörü çalışması gerçekleştirilmiştir.

### 5.2. Araştırmada Kullanılan Değişkenler ve Veri Seti

Bu çalışmada, Ocak 2010-Haziran 2019 dönemine ait aylık verilerden yararlanılmıştır. Bağımsız değişken olarak seçilen Kredi Temerrüt Swapları (CDS) verileri Paragaranti veri tabanından ve Tahvil Faizi (Türkiye 2 Yıllık) verileri Investing veri tabanından alınmıştır. Diğer bağımsız değişkenler olan; Üretici Fiyat Endeksi (ÜFE), Para Arzı (M1), Döviz Kuru Sepeti (USD-EURO), Kredi Hacmi (Yurtiçi Banka Bilançoları Toplamı) ile bağımlı değişken olan Ticari Kredi Faiz Oranlarına ait veriler ise Elektronik Veri Dağıtım Sisteminden (EVDS) alınmıştır.

### 5.3 VAR Modelinin Uygulanması

Çalışmanın bu bölümünde VAR Modelinin birim kök test sonuçları gösterilmiş, gecikme sayısı belirlenerek tahmin ve öngörü sonuçlarına yer verilmiştir.

#### 5.3.1. Verilerin durağanlaştırılması (Birim kök testleri)

VAR Modelinin ilk adımında yapılması gereken serilerin durağan olup olmadığının incelenmesidir. Çünkü durağan olmayan bir seri sadece ele alınan bir dönem için geçerli olmaktadır. Birim kök testleri serinin durağan olup olmadığına karar verebilmek için kullanılan testlerdir. Seri durağan değilse birim köke sahip, durağansa birim köke sahip değildir. Augmented Dickey-Fuller (ADF) birim kök testi ve Philips-Perron (PP) birim kök testi test istatistiklerinin sabitli ve sabitli trendli verilerine bakıldığında; ele alınan yedi değişkenin düzeyde durağan olmadığı yani serinin ortalaması etrafında dağılmadığı görülmektedir. Değişkenlerin birinci farkları alındığında durağanlaşma varsayımını sağladıkları Tablo 3'te görülmektedir.



**Tablo 3.** ADF ve PP Birim Kök Testi Sonuçları

Değişkenler	ADF(sabit)	ADF (Trend-Sabit)	PP(sabit)	PP (Trend-Sabit)
LOGTKFO	-7.0384	-7.0168	-6.7945	-6.7670
LOGCDS	-11.4698	-11.4508	-11.5068	-11.4923
LOGM1	-3.4080	-3.3887	-14.1917	-14.1156
LOGSEPET	-8.2106	-8.4068	-7.3433	-7.3135
LOGTF	-10.1558	-10.2582	-10.3182	-11.4142
LOGUFE	-6.9262	-7.3321	-6.1042	-5.9360
LOGYIKH	-8.2268	-8.8840	-8.2285	-8.7781

### 5.3.2. VAR Modelinde gecikme sayısının belirlenmesi

VAR Modelinde yapılması gereken diğer bir adım ise gecikme uzunluğunun belirlenmesidir. Fakat uygun gecikme sayısı seçiminde bazı güçlüklerle karşılaşılabilir. Örneğin, üç değişkenin yer aldığı bir VAR modelinde, her bir denklemde bulunan değişkenin sekiz gecikmesi olduğu varsayılın yani bu ise yirmi dört gecikmeli parametre ve sabit terim bulunacağı anlamına gelmektedir. Bunun sonucunda ise örnek uzayı boyutu büyük olmadığı sürece, tahmininde bulunulan çoğu parametre serbestlik derecesini tüketir ve bunun sonucu olarak da modelde yer alan parametrelerin tahmini zorlaşır (Gujarati, 1995).

VAR Modelinin gecikme uzunluğuna olan duyarlılığından dolayı bu model için gecikme sayısı seçimi oldukça önemlidir. Oluşan modelin gecikme uzunluğu, olduğundan küçük seçilirse, parametre tahminlerinin değişkenliği fazla çıkmaktadır. Eğer büyük seçilir ise parametreler yanlış tahminler vermektedir (Sevüktekin ve Nargeleçekenler, 2007:53). Gecikme uzunluğunun belirlenmesinde bakılan, Akaike Bilgi Kriteri (AIC), Schwartz Kriteri (SIC), Hannan ve Quinn Kriteri (HQ), Shibate Kriteri gibi farklı yöntemler mevcuttur. Yapılan çalışmada yararlanılan gecikme uzunluğu kriterleri ise AIC, SIC ve HQ Kriterleridir. Gecikme uzunluğu seçimine veriler aylık olduğundan dolayı on iki ile başlanmış, daha sonra azaltılarak ilerlenmiştir. Tablo 5’de SIC ve AIC kriterlerinin verdiği değerler gösterilmiştir. Bu değerlere göre gecikme uzunluğu AIC için on iki, SIC ve HQ için ise bir olarak saptanmıştır.

Lütkepohl’un Monte Carlo Simülasyon çalışmalarında SIC kriterinin diğer kriterlere bakılarak daha iyi sonuçlar verdiğini ortaya koymuştur. Bu sebeple çalışmada bir gecikme uzunluğu dikkate alınmıştır (\* uygun gecikme uzunluğunu göstermektedir).

**Tablo 4.** Gecikme Uzunluğunun Belirlenmesi

Lag	LogL	LR	FPE	AIC	SIC	HQ
0	1951.357	NA	4.48e-26	-38.50211	-38.32086	-38.42874
1	2083.138	242.6869	8.72e-27*	-40.14135	-38.69138*	-39.55436*
2	2109.495	44.88513	1.38e-26	-39.69297	-36.97428	-38.59237
3	2153.338	68.58636	1.59e-26	-39.59086	-35.60345	-37.97664
4	2191.182	53.95577	2.11e-26	-39.36995	-34.11381	-37.24211
5	2247.192	72.09195	2.06e-26	-39.50876	-32.98390	-36.86731
6	2286.383	45.01100	2.98e-26	-39.31451	-31.52093	-36.15945
7	2353.057	67.33410*	2.73e-26	-39.66449	-30.60219	-35.99581
8	2412.291	51.60973	3.26e-26	-39.86714	-29.53612	-35.68485
9	2483.246	51.98698	3.65e-26	-40.30190	-28.70216	-35.60599
10	2582.834	59.16150	2.95e-26	-41.30365	-28.43519	-36.09413
11	2709.795	57.82378	2.03e-26	-42.84743	-28.71025	-37.12429
12	2892.874	58.00526	8.95e-27	-45.50246*	-30.09656	-39.26571

### 5.3.3. VAR Modeli ile tahmin değerlerinin elde edilmesi

Bu çalışmada VAR ve YSA NARX Modellerinin tahmin başarısını ölçmek için Ortalama Mutlak Sapma (Mean Absolute Deviation-MAD), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE), Ortalama Hata Kareleri (Mean Square Error-MSE) ve Hata Kareleri Ortalamasının Karekökü ( Root Mean Square Error-RMSE) performans ölçütleri kullanılmıştır. Ortalama hata kavramını temel alan ve yaygın şekilde kullanılan başlıca bu performans ölçütlerinin formülleri Eşitlik 10, Eşitlik 11, Eşitlik 12, Eşitlik 13’te verilmiştir.

Denklemden yer alan  $e_t$  t dönemi için tahmin hatasını göstermektedir.  $F_t$  t dönemi için tahmin değeri ve  $D_t$  ise t dönemi için gerçekleşen değeri olması durumunda tahmin hatası Eşitlik 9’da görülmektedir.

$$e_t = D_t - F_t \quad (9)$$

n dönemde gerçekleşen tahmin hataları  $e_1, e_2, \dots, e_n$  olması durumunda aşağıdaki formüller kullanılarak sonuca ulaşılmaktadır.

$$MAD = (1/n) \sum_{i=1}^n |e_i| \quad (10)$$

$$MSE = (1/n) \sum_{i=1}^n |e_i|^2 \quad (11)$$

$$RMSE = \sqrt{(1/n) \sum_{i=1}^n e_i^2} \quad (12)$$

$$MAPE = (100/n) \sum \left| \frac{e_i}{y_t} \right| \quad (13)$$

Uygulamada kullanılan Ocak 2010- Haziran 2019 dönemlerine ait veri seti programa girilerek VAR Modeli ile ticari kredi faiz oranlarının tahmini gerçekleştirilmiştir. Tahmin değerleri için hesaplanan MAD, RMSE, MSE ve MAPE performans ölçütleri Tablo 5’te gösterilmektedir.

**Tablo 5.** Tahmin Değerleri İçin Hesaplanan MAD, MSE, MAPE ve RMSE

Performans Ölçütleri	Performans Ölçüt Değerleri
MAD	2.69495
MSE	10.76881
RMSE	3.281589
MAPE	18.28702

#### 5.3.4. VAR Modeli ile öngörü değerlerinin elde edilmesi

VAR Modeli ile yapılan ticari kredi faiz oranlarının Temmuz 2019 - Haziran 2020 dönemine kadar on iki aylık öngörüsü gerçekleştirilmiş ve on iki aylık verinin Temmuz 2019-Aralık 2019 dönemleri açıklandığından dolayı öngörü değerlerinin başarısını ölçmek amacıyla gerçek değerler ile öngörü değerleri arasındaki MAD, MSE, RMSE ve MAPE performans ölçütlerine bakılmıştır. Bulunan değerlere ise Tablo 6’da yer verilmiştir.

**Tablo 6.** VAR Modelinin 6 Aylık Tahmin ve Performans Ölçüt Değerleri

Tarihler	Gerçek Değerler	Tahmini Değerler	Performans Ölçütleri	Performans Ölçüt Değerleri
07.2019	23.945	26.1016	MAD	9.03157
08.2019	19.910	26.3474	MSE	96.94534
09.2019	18.235	26.5955	RMSE	9.84608
10.2019	15.955	26.8460	MAPE	57.15089
11.2019	14.112	27.0987		
12.2019	13.9967	27.3539		

Tablo 7’de ise Ocak 2019- Haziran 2020’ye kadar olan altı aylık öngörü değerleri görülmektedir.

**Tablo 7.** VAR Modelinin 6 Aylık Öngörü Değerleri

Tarihler	Öngörü Değerleri
01.2020	27.6115
02.2020	27.8715
03.2020	28.1340
04.2020	28.3989
05.2020	28.6663
06.2020	28.9362

#### 5.4. YSA NARX Modelinin Uygulanması

YSA’da uygulamaya başlamadan önce verilerin normalize edilmesi gerekmektedir. Literatürde birçok normalizasyon tekniği bulunmaktadır. Ancak Yavuz ve Deveci (2012:185) yaptıkları “İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağının Performansına Etkisi” isimli çalışmalarında, normalizasyon

teknikleri üzerinde durmuş ve bu tekniklerden yararlanarak hava tahmininde hangisinin daha iyi sonuç verdiğini araştırmışlardır. Araştırmanın sonucunda en iyi sonucu veren normalizasyon tekniğinin D\_Min\_Max olduğu kanısına varmışlardır. Bu çalışmada da bu teknikten yararlanılmış ve Eşitlik 8’de yer alan formüle göre verilerin normalizasyonu gerçekleştirilmiştir.

$$x' = 0.8 \times \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (8)$$

Eşitlikte yer alan “x” normalize edilmiş veriyi, “x<sub>i</sub>” girdi değerini, “x<sub>min</sub>” girdi seti içerisinde yer alan en küçük sayıyı, “x<sub>max</sub>” ise girdi seti içerisinde yer alan en büyük sayıyı ifade etmektedir.

#### 5.4.1. Optimal YSA NARX Modelinin eğitimi ve testi

YSA NARX modelinin optimal mimarisinin açıklanması, eğitim ile doğrulama için veri üretiminin sağlanmasını ayrıca minimum MSE’yi çıkaran mimarinin tercihini içermektedir. En az MSE’ye sahip olan mimari ise gizli katmanda yer alan nöronların değiştirilmesi, gecikme sayısının değiştirilmesi, eğitim, doğrulama ve test yüzdeliklerinin değiştirilmesi ile seçilmektedir (Manonmani vd., 2016:920).

Eğitim kümesinin amacı ağı öğrenmesini sağlamaktır. Doğrulama kümesinin amacı ise en iyi modelin seçimine yardımcı olmaktır. Bu şekilde çok kez eğitiminde bulunmuş bir ağ ile tahminde bulunma riskinin aza indirgenmesi mümkün olmaktadır (Hamzaçebi, 2005:123).

Bu çalışmada Matlab R2016b programında yer alan ntstool aracı içinde bulunan NARX modeli kullanılarak oluşturulan YSA modeli çözümlenmeye çalışılmıştır. Bağlantıda yer alan ağırlıklar eğitim aşamasının başlangıcında rassal şekilde belirlenmiştir. Model oluşturulurken Ocak 2010-Haziran 2019 dönem aralığına ait aylık veriler kullanılmıştır. Gecikme uzunluğu VAR modeli SIC kriterine göre seçilen bir gecikme sayısı olarak alınmıştır.


Uygulamada oluşturulan modellerin MAD, MSE, MAPE ve RMSE değerleri Tablo 8’de görülmektedir. Bunların dışında birçok model denemiş ancak performans ölçüt değerleri yüksek çıkmıştır.

**Tablo 8.** Öğrenme, Doğrulama ve Test Değerleri İçin Hesaplanan MAD, MSE, RMSE ve MAPE Değerleri

Performans Ölçütleri	%80 eğitim	%75 eğitim	%70 eğitim	%65 eğitim	%60 eğitim
	%10doğrulama	%15doğrulama	%15doğrulama	%15doğrulama	%20doğrulama
	%10 test	%10 test	%15 test	%20 test	%20 test
	<b>15 nöron</b>	<b>25 nöron</b>	<b>20 nöron</b>	<b>20 nöron</b>	<b>10 nöron</b>
MAD	0.30474	0.57836	0.44169	0.37049	0.54297
MSE	0.17545	0.57347	0.50442	0.23888	0.71848
RMSE	0.41887	0.75728	0.71023	0.48876	0.84763
MAPE	2.33573	4.56717	3.01160	2.75319	3.51765

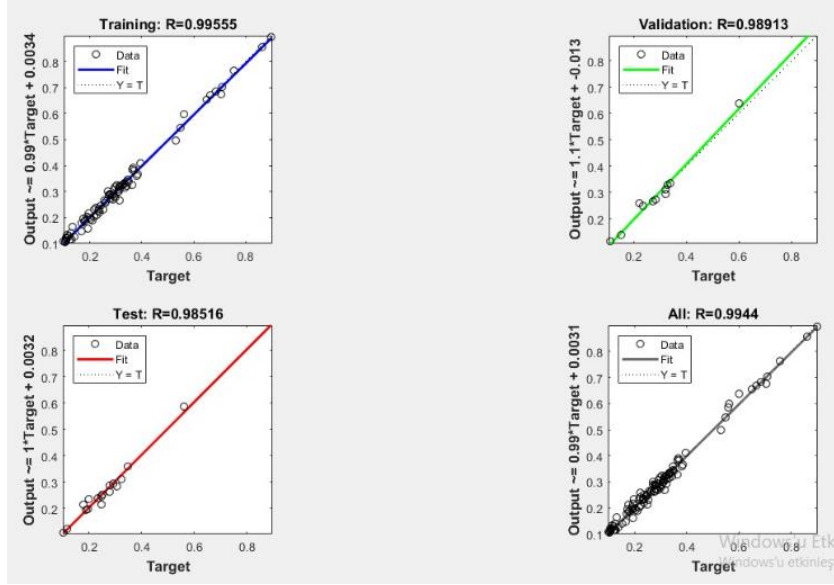
Tablo 8’de verilen MAD, MSE, RMSE ve MAPE değerlerinin düşük olması ağın iyi öğrendiğini kanıtlamıştır. En iyi tahminlemeyi ise %80 eğitim, %10 doğrulama ve %10 test modeli gerçekleştirmiştir. Şekil 7’de ise bu modelin kapalı döngü NARX modeli yer almaktadır.

Şekil 3’de yer alan modelde x(t) bağımsız değişken sayısını, y(t) ise bağımlı değişken sayısını göstermektedir. Bu modelde ağ iki giriş katmanı, bir gizli katman ve bir adet de çıkış katmanına sahiptir. Gizli katmanda on beş, çıkış katmanında ise bir adet nöron yer almaktadır.



**Şekil 3.** Oluşturulan Kapalı Döngü NARX Modeli

Eğitim işleminin başarısını R (Regresyon) parametresi ve hata oranı belirlemektedir. Ayrıca iki veya daha fazla değişkenin birbirleri ile olan ilişkisini ölçmek içinde regresyon analizi kullanılmaktadır. Eğitim, doğrulama, test ve tüm aşamalar için bulunan regresyon sonuçlarına Şekil 4’de yer verilmiştir. Şekilde hedeflenen değer 1’e oldukça yakın olduğu görülmektedir.



Şekil 4. Regresyon Analizi Grafiksel Sonuçları

#### 5.4.2 YSA NARX Modeli ile öngörü sonuçlarının elde edilmesi

Tablo 9’da belirlenen eğitim, doğrulama ve test modelleri için ticari kredi faiz oranlarının Temmuz 2019-Haziran 2020 dönemine kadar on iki aylık öngörüsü gerçekleştirilmiştir. Fakat bulunan on iki aylık verinin Temmuz 2019-Aralık 2019 dönemleri açıklandığından dolayı öngörü değerlerinin başarısını ölçmek amacıyla gerçek değerler ile öngörü değerleri arasındaki MAD, MSE, RMSE ve MAPE değerleri hesaplanmış ve Tablo 10’da verilmiştir.

Tablo 9. YSA NARX Tüm Modeller İçin Altı Aylık Tahmin ve Performans Ölçüt Değerleri

Performans Ölçütleri	%80 eğitim	% 75 eğitim	% 70 eğitim	% 65 eğitim	% 60 eğitim
	% 10 doğrulama	% 15 doğrulama	% 15doğrulama	% 15doğrulama	% 20 doğrulama
	% 10 test	% 10 test	% 15 test	% 20 test	% 20 test
	15 nöron	25 nöron	20 nöron	20 nöron	10 nöron
MAD	1.26039	0.87505	1.36829	1.24175	1.78855
MSE	1.95766	1.23038	2.56264	2.43950	4.89054
RMSE	1.39916	1.10923	1.60083	1.56189	2.21146
MAPE	6.99736	4.81570	8.29109	6.74584	9.14203

Tablo 9’da yer alan modellerin performans ölçütleri incelendiğinde en iyi modelin %75 eğitim, %15 doğrulama ve %10 test seçilen model olan grup olduğu görülmektedir. Tablo 10’da ise en iyi model için elde edilen tahmin ve performans ölçüt değerlerine yer verilmiştir.

Tablo 10. YSA NARX En iyi Modeli İçin 6 Aylık Tahmin ve Performans Ölçüt Değerleri

Tarihler	Gerçek Değerler	Tahmini Değerler	Performans Ölçütleri	Performans Ölçüt Değerleri
07.2019	23.945	26.0374	MAD	0.875885
08.2019	19.910	20.2611	MSE	1.230978
09.2019	18.235	17.4684	RMSE	1.109495
10.2019	15.955	15.5221	MAPE	4.821409
11.2019	14.112	13.9421		
12.2019	13.997	12.5542		


Tablo 11’de ise Ocak 2020- Haziran 2020’ye kadar bulunan 6 aylık öngörü değerleri görülmektedir.

**Tablo 11.** YSA NARX Modeli 6 Aylık Öngörü Değerleri

Tarihler	Öngörü Değerleri
01.2020	11.2869
02.2020	10.1185
03.2020	9.0570
04.2020	8.1263
05.2020	7.3504
06.2020	6.7404

### 5.5. YSA NARX ve VAR Modellerinin Öngörülerinin Karşılaştırılması

Uygulama sonucunda iki modelin sonuçları Grafik 1’de karşılaştırılmıştır. Doğrusal olmayan bir modelleme yöntemi olan YSA NARX Modelinin doğrusal bir yöntem olan VAR Modeline göre oldukça iyi sonuçlar verdiği görülmüştür.



**Grafik 1.** YSA NARX ve VAR Modellerinin 6 Aylık Tahmin Sonuçları

## 6. SONUÇ VE TARTIŞMA

Türkiye gibi finansal piyasaların aşırı değişken, kırılğan, siyasi ve toplumsal risklere karşı oldukça duyarlı olduğu gelişmekte olan ülkelerde makroekonomik değişkenlerin durağan bir ekseninde yer alması çoğu zaman mümkün olmamaktadır. Türkiye’de son yirmi yıl içinde biri ulusal (2001) biri uluslararası (2008) kaynaklı olmak üzere iki ayrı finansal kriz yaşanmıştır. Ayrıca 2018 ve 2019 yılı içinde döviz kurlarında ortaya çıkan artışlarda ülke ekonomisini olumsuz şekilde etkilemiştir. Bunun yanında siyasi alanda yaşanan krizlerin (2008 kapatma davası ve 2013 Gezi olayları, 15 Temmuz 2016 darbe girişimleri) varlığı da bu tespiti doğrulamaktadır.

Türkiye’ye benzer istikrar sorunu yaşayan ekonomilerde, zaman serisi veri setine dayalı regresyon analizleri yoluyla yapılan öngörü çalışmalarından isabetli sonuçlar almak oldukça zor hale gelmektedir. Bunun yerine, çoğu zaman durağanlığını yitirebilen değişkenlerin doğrusal olmayan ilişkilerinin varlığını modelleyebilen yöntemlere ihtiyaç duyulmaktadır. YSA NARX Modeli de bu yöntemlerden biridir.

Bu çalışmada, ticari kredi faiz oranları ile ilgili öngörü çalışması için Ocak 2010- Haziran 2019 dönemi verileri kullanılmıştır. YSA NARX Modeli ile yapılan öngörü çalışmasının performansı doğrusal model özelliğine sahip öngörü gücü yüksek bir modelleme tekniği olan VAR Modeli ile karşılaştırılmış ve YSA NARX Modelinin oldukça iyi sonuçlar verdiği görülmüştür. YSA NARX Modeli çoklu değişkenlerle bir arada çalışmaya olanak sağlayan ve yüksek doğrulukta tahminler veren bir yöntemdir. Çalışmada yer alan iki ayrı yöntemle ait tahmin sonuçları da bu tespiti doğrulamaktadır.

Bu bağlamda önemli bir makroekonomik gösterge olan ticari kredi faiz oranlarının tahmini ve öngörüsü için doğrusal olmayan modellemenin daha iyi sonuçlar vereceği kanısına varılmıştır.

Kredi faiz oranlarının doğru tahmin edilmesi ekonomi dünyasındaki paydaşlara önemli faydalar sağlayacaktır. Bu çalışma ile elde edilen sonuçlar, bireysel ve kurumsal yatırımcılar, üretim yapan işletmeler, finans kuruluşları ve mali politikaları hayata geçiren kamu kurumları için oldukça önemlidir. Bireysel ve kurumsal yatırımcılar ticari kredi faiz oranlarından yola çıkarak fon getirilerini yani vadeli mevduat faiz

oranlarını ve tahvil getirilerini tahmin etmeye çalışabilir. Böylece fon yönetiminde karar alma sürecini etkileyen temel bir bilgiye ulaşmış olurlar. İşletmeler ileride kendilerini bekleyen fon maliyetlerini erkenden tahmin edebilirse borçlanma maliyetlerinin işletmenin mali yapısını nasıl etkileyebileceği konusunda fikir sahibi olurlar. Bunun yanında ticari kredi faiz oranlarının başarılı tahmini işletmelerin büyüme amacıyla yatırım yapıp yapmama konusunda karar vermelerini kolaylaştıracaktır. İleride kredi faiz oranlarının yükselmesini bekleyen işletmeler dış kaynak kullanarak büyüme yerine büyümeyi veya özsermaye yoluyla büyümeyi tercih edebilir. Finans kuruluşları fon fazlası olan birimlerden sağladıkları kaynağı, fon ihtiyacı olan birimlere kullandırarak gelir elde etmeye çalışır. Burada amaç fon toplamak için kullandığımız maliyetten daha yüksek oranda getiri elde etmeye çalışmaktır. Finans kuruluşları kredi faiz oranlarının hangi seviyelerde gerçekleşebileceğini tahmin ederse maliyetlerini de buna göre ayarlayacaktır. Dolayısıyla risklerini minimize edeceklerdir. Kredi faiz oranlarının doğru tahmini kamu kurumları açısından da oldukça önemlidir. Tahminleme doğru yapılırsa makroekonomik değişkenlerin ileride hangi noktalara ulaşacağı politika yapıcıların işlerini kolaylaştıracaktır. İşletmeler için dış kaynak kabul edilen ticari kredi faiz oranlarının doğru tahmin edilmesi ekonomik kesimde yer alan paydaşların neredeyse tamamı açısından önemlidir. Çalışmanın bu yönüyle de ulusal ve uluslararası literatüre katkı sağlayacağı düşünülmektedir.

### KAYNAKÇA

- Aderemi, A.A.A., Adewumi, A. O. ve Ayo, C. K. (2014). Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction, *Journal of Applied Mathematics*, 2014(1), 1-7.
- Ak, R., Fink, O. ve Zio, E. (2016). Two Machine Learning Approaches for Short-Term Wind Speed Time-Series Prediction, *IEEE Transactions on Neural Networks and Learning Systems Journal*, 27(8), 1734–1747.
- Altan, Ş. (2008). Döviz Kuru Öngörü Performansı İçin Alternatif Bir Yaklaşım: Yapay Sinir Ağı, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(2), 141-160.
- Aşkın, D., İskender, İ. ve Mamızadeh, A. (2011). Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi, *Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 26(4), 905-913.
- Ayla, D. (2019). Türkiye’de Faiz Oranı ve Döviz Kuru, *Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(17), 289-308.
- Aytekin, S. ve Dube, S. (2016). Piyasalar Arası Dinamikler: Hisse Senedi, Tahvil, Döviz ve Emtia Piyasaları Arasındaki Etkileşim ve Nedensellik İlişkileri, *Elektronik Sosyal Bilimler Dergisi*, 15(59), 1311-1326.
- Benazić, M. (2013). Testing the Fisher Effect in Croatia: An Empirical Investigation, *Economic Research*, 26(1), 83-102.
- Booth, G. G. ve Ciner, Ç. (2001). The Relationship Between Nominal Interest Rates and Inflation: International Evidence, *Journal of Multinational Financial Management*, 11(3), 269-280.
- Cadenas, E., Rivera, W., Amezcua, R. C. ve Heard, C. (2016). Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model, *Energies*, 9(2), 1-15.
- Cesur, F. (2006). Para Arzı ile Enflasyon İlişkisi ve Türkiye Uygulaması (1994-2004), *Trakya Üniversitesi Sosyal Bilimler Dergisi*, 8(2), 85-104.
- Cheng, B. ve Tittleington, D.M. (1994). Neural Networks: A Review From a Statistical Perspective, *Statistical Science*, 9 (1), 2–54.
- Claveria, O. ve Torra, S. (2014). Forecasting Tourism Demand to Catalonia: Neural Networks vs. Time Series Models, *Economic Modelling*, 36, 220-228.
- Conkar, M. K. ve Vergili, G. (2017). Kredi Temerrüt Swapları İle Döviz Kurları Arasındaki İlişki: Türkiye İçin Ampirik Bir Analiz, *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(4), 59-66.
- Davidson, R. ve Mackinnon, J.G. (1993). Estimation and Inference in Econometrics, Oxford, İngiltere: Oxford University Pres.

- Demir, M. ve Sever, E. (2008). Kamu İç Borçlanmasının Büyüme, Faiz ve Enflasyon Oranı Üzerindeki Etkileri, *Elektronik Sosyal Bilimler Dergisi*, 7(25), 170-196.
- Demirgil, B. ve Türkay, H. (2017). Türkiye'de Faiz Oranlarını Etkileyen Faktörler: Bir ARDL/Sınır Testi Uygulaması, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(3), 907-928.
- Dohnal, J. (2004). Using of Levenberg-Marquardt Method in Identification by Neural Networks, *In Student EEICT 2004. Student EEICT 2004. Brno: Ing. Zdeněk Novotný CSc.*,361 – 365.
- Erdoğan, E. ve Özyürek, H. (2012). Yapay Sinir Ağları ile Fiyat Tahminlemesi, *Sosyal ve Beşeri Bilimler Dergisi*, 4(1), 85-92.
- EVDS (Elektronik Veri Dağıtım Sistemi), (2020). Fiyat Endeksi (Yurt İçi Üretici Fiyatları)(2003=100)(TÜİK)(NACE REV.2)(Aylık), <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, (Erişim Tarihi: 8 Aralık 2020).
- EVDS (Elektronik Veri Dağıtım Sistemi), (2020). Kurlar-Döviz Kurları(Günlük)(Aylık Frekans), <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, (Erişim Tarihi: 8 Aralık 2020).
- EVDS (Elektronik Veri Dağıtım Sistemi), (2020). M1 – Düzey(Aylık), <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, (Erişim Tarihi: 8 Aralık 2020).
- EVDS (Elektronik Veri Dağıtım Sistemi), (2020). Ticari (TL Üzerinden Açılan)(Akım Veri,%)(Aylık) – Düzey (Aylık), <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, (Erişim Tarihi: 8 Aralık 2019).
- EVDS (Elektronik Veri Dağıtım Sistemi), (2020). Yurt İçi Kredi Hacmi, Bankacılık Sektörü (Bin TL)(Aylık), <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, (Erişim Tarihi: 8 Aralık 2020).
- Ferrari, S. ve Jensenius, M. (2008). A Constrained Optimization Approach to Preserving Priorknowledge During Incremental Training, *IEEE Transactions on Neural Networks and Learning Systems*, 19(6), 996–1009.
- Greene, W. H., (1993). *Econometric Analysis*, Upper Saddle River, New Jersey: Prentice-Hall.
- Gujarati, D. N. (1995). *Basic Econometrics*, New York: McGraw-Hill Higher Education.
- Hagan, M.T. ve Menhaj, M.B. (1994). Training Feedforward Networks With the Marquardt Algorithm, *IEEE Transactions on Neural Networks*, 5(6), 989–993.
- Ham, F.M. ve Kostanic, I. (2003). *Principles of Neurocomputing for Science&Engineering*, New York: McGrawHill Education.
- Hamzaçebi, C. (2005). Geleceği Tahminde Yapay Sinir Ağları İçin Sezgisel Öğrenme Algoritması, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Haykin, S. (1998). *Neural Networks: A Comprehensive Foundation*, Upper Saddle River, NJ, USA: Prentice Hall PTR.
- Helhel, Y. (2009). Makroekonomik Değişkenler ve Döviz Kuru İlişkisi: Yapay Sinir Ağı ve VAR Yaklaşımları ile Öngörü Modellenmesi, Doktora Tezi, Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü, Isparta.
- Investing.com, (2020). Türkiye 2 Yıllık Tahvil Verimi, Türkiye 2 Yıllık Tahvil Verimi(Aylık), <https://tr.investing.com/rates-bonds/turkey-2-year-bond-yield-historical-data>, (Erişim Tarihi: 08 Aralık 2020).
- İslamoğlu, E. (2015). Aralık Değerli Zaman Serilerinde Kullanılan Modelleme Teknikleri, *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 8(2), 178–193.
- Lasheras , F.Z., Juez, F. S., Sanchez, A. S., Krzemien, A. ve Fernandez, P. R. (2015). Forecasting the COMEX Copper Spot Price by Means of Neural Networks and ARIMA Models, *Resources Policy*, 45, 37-43.
- Leigh, D. ve Rossi, M. (2002). Exchange Rate Pass- Through İn Turkey, *IMF Working Paper*, 1-18.

- Kirbaş, İ. ve Kerem, A. (2016). Short-Term Wind Speed Prediction Based on Artificial Neural Network Models, *Measurement and Control*, 49(6), 183-190.
- Khosravi, Z.M.H., Barghinia, S. ve Ansarimehr, P. (2006). New momentum Adjustment Technique for Levenberg-Marquardt Neural Network Used in Short Term Load Forecasting, *in Proc. of 21st International Power System Conference*, Tehran, Iran.
- Lin, T., Horne, B.G., Tino, P. ve Giles, C.L., (1996). Learning Long-term Dependencies in NARX Recurrent Neural Networks, *IEEE Transactions on Neural Networks*, 7(6), 1329-1338.
- Maitra, B. (2018). Determinants of Nominal Interest Rates in India, *Journal of Quantitative Economics*, 16(1), 265–288.
- Manonmani, A., Thyagarajan, T., Elango, M. ve Sutha S. (2018). Modelling and Control of Greenhouse System Using Neural Networks, *Transactions of the Institute of Measurement and Control*, 40(3), 918–929.
- Masatçı, K., ve Darıcı, B. (2006). Türkiye’de Faiz Oranlarının Belirlenmesinde İçsel ve Dışsal Faktörlerinin Rolü, *Yönetim ve Ekonomi Araştırmaları Dergisi*, 4(6), 18-31.
- Nesanır, Ö. (2011). Türkiye’de Para Arzı-Banka Kredileri İlişkisi: VAR Analizi(1986-2010), *Sosyal Bilimler Dergisi*, 1(2), 115-133.
- Özpinar, Ö., Özman, H., ve Doru, O. (2018). Kredi Temerrüt Takası (CDS) ve Kur-Faiz İlişkisi Türkiye Örneği, *Bankacılık ve Sermaye Piyasası Araştırmaları Dergisi-BSPAD*, 2(4), 31-45.
- Panda, C. ve Narasimhan, V. (2007). Forecasting Exchange Rate Better With Artificial Neural Network, *Journal of Policy Modeling*, 29(2), 227-236.
- Paragaranti, (2020). CDS (Aylık), Paragaranti.com: <https://www.paragaranti.com/cds> (Erişim Tarihi: 8 Aralık 2019).
- Ripley, B.D. (1993). Statistical aspects of neural networks. In: experts: An empirical test. In: Barndorff-Nielsen, O.E., Jensen, J.L., Kendall, W.S. (Eds.), *Networks and Chaos-Statistical and Probabilistic Aspects*, London: Chapman and Hall, 40–123.
- Sever, E., ve Mızrak, Z. (2007). Döviz Kuru, Enflasyon ve Faiz Oranı Arasındaki İlişkiler: Türkiye Uygulaması, *Sosyal Ekonomik Araştırmalar Dergisi*, 7(3), 264-283.
- Sevüktekin, M. ve Nargeleşkenler, M. (2007). Finansal Faktörlerin Reel Para Talebi Üzerindeki Rolü: Türkiye Örneği, *Balikesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(18), 45-61.
- Sims, C., (1980). “Macroeconomics and Reality”. *Econometrica*, 48(1), 1-48.
- Tatlı, A.ve Kahvecioğlu, S. (2016). Zaman Serilerinde NARX Sinir Ağları Modeliyle Uçuşa Elverişlilik Süresinin Kestirimi, *ELECO’2016 Elektrik, Elektronik ve Biyomedikal Mühendisliği Konferansı*, 1Aralık 2016, Bursa, 130-134.
- Telçeken, H., ve Değirmen, S. (2019). Enflasyon ve Kredi Faizleri Arasındaki Uzun Dönemli İlişkinin Fisher Hipotezi Çerçevesinde Değerlendirilmesi Türkiye Uygulaması (2002-2018), *Istanbul Business Research*, 47(2), 154-182.
- Valipour, M., Banihabib, M. E., Mahmood, S. ve Behrahani, R. (2013). Comparison of The ARMA, ARIMA, and The Autoregressive Artificial Neural Network Models in Forecasting the Monthly Inflow of Dez Dam Reservoir, *Journal of Hydrology*, 476, 433-441.
- Werbos, P.J. (1988). Back-Propagation: Past and Future, *in Proc. International Conference Neural Networks*, San Diego, CA, 1, 343–353.
- Were, M. Ve Wambua, J. (2013). Assessing The Determinants of Interest Rate Spread of Commercial Banks in Kenya: An Empirical Investigation, *KBA Centre for Research on Financial Markets and Policy(WPS/01/13)*, 1-25.



- Wijaya, Y. B. ve Napitupulu, T. A. (2010). Stock Price Prediction: Comparison of ARIMA and Artificial Neural Network Methods - An Indonesia Stock's Case, *Second International Conference on Advances in Computing, Control, and Telecommunication Technologies*, 176-179.
- Wilamowski, B.M. ve Chen, Y. (1999). Efficient Algorithm for Training Neural Networks with one Hidden Layer, in *Proc. of the International Joint Conference on Neural Networks*, 3, 1725-1728.
- White, H. (1989). Learning in Artificial Neural Networks: A Statistical Perspective, *Neural Computation*, 1(4), 425-464.
- Xie, H., Tang, H. ve Liao, Y. (2009). Time Series Prediction Based on NARX Neural Networks: An Advanced Approach, In: *2009 International Conference on Machine Learning and Cybernetics*, 3, 1275-1279.
- Yaşar, S. (2006). Firma Finansmanında Hisse Senedi Piyasalarının Rolü: Türkiye Örneği, Ankara: Sermaye Piyasası Kurulu.
- Yavuz, H. H. (2012). Tahvil Piyasası Oynaklığının Belirlenmesinde Makroekonomik Değişkenlerin Oynaklığının Analizi, *Maliye ve Finans Yazıları*, 1(96), 15-33.
- Yavuz, E. (2018). Yapay Sinir Ağı Kullanılarak Kontrol Alan Ağları İçin Çevrem İçerisinde Mesaj Zamanlaması Optimizasyonu, Doktora Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta.
- Yavuz, S. ve Deveci, M. (2012). İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187.
- Zhang, G. P., Patuwo, B. E. ve Hu, M. Y. (1998). Forecasting With Artificial Neural Networks: The State Of The Art, *International Journal Of Forecasting*, 14(1), 35-62.